

# 注視機構実現に向けた視覚-行動学習による 画像特徴と状態空間の構成

港 隆史\* 浅田 稔\*

## Image Feature and State Space Construction by Visio-Motor Learning towards Visual Attention

Takashi Minato\* and Minoru Asada\*

Visual attention is one of the key issues for robots to accomplish the given tasks, and the existing methods specify the image features and attention control scheme in advance according to the task and the robot. However, in order to cope with environmental changes and/or task variations, the robot should construct its own attention mechanism. This paper presents a method for image feature and state space construction by visio-motor learning for a mobile robot towards visual attention. The learning model which consists of the image feature generation and state vector estimation is suggested by a visual cortex architecture. The teaching data constructs the visio-motor mapping that constrains the image feature and state space construction as well. The method is applied to indoor navigation and soccer shooting tasks, and discussion is given.

**Key Words:** Image feature, State space, Task-oriented, Entropy, Visual attention

### 1. はじめに

ロボットの知能の発達にとって、注意の形成は複数ロボットの協調、コミュニケーション、効率的学习を可能にする重要な課題である。視覚において注意の問題は、多くの情報の中からタスクに必要な情報を抽出する機構の構築問題となる。すなわちロボットがタスク達成に必要な行動を決定するために、何を注視し、それからどのような情報を抽出するかを決定する問題となる。このような問題において、従来では設計者があらかじめロボットにとってタスク遂行に必要と考えられる注視対象を決定していた。しかし自律ロボットがタスクや環境の変化に適應するためには、ロボット自身がタスクや環境に応じた注視機構を構築する能力を持つことが望まれる。

注視対象を決定する問題を扱った研究として、人間の初期視覚過程を解明するための視覚探索研究 [1]~[4] や画像上の情報量に基づいて注視場所を決定する研究 [5] がある。前者では、注視目標対象が与えられたときに、対象を発見するまでの視野内での視点の移動方法が提案されている。後者では視野内で視点を移動させる基準として、輝度の情報量を用いた手法を提案している。またコンピュータビジョンの分野では物体認識のための視点決定に関する研究で、物体を識別しやすいカメラ視点を情報量的基準で決定する手法 (たとえば [6]) が提案されている。

しかし以上の研究ではタスクが視覚情報処理の範囲で閉じているため、注視対象を決定する基準が画面上の情報のみに基づいている。そのためロボットの行動を伴うタスクを注視対象の決定基準に反映させることができない。

ロボットの位置同定に関する研究では、Thrun [7] や Vlassis et al. [8] は観測画像とそれを観測したときに教示された位置データを用いて、ロボットの位置推定に必要な特徴ベクトルを観測画像から計算する手法を提案している。これらの手法では教示された位置と特徴ベクトルとの相関が高くなるように、確率的手法を用いて特徴ベクトルを学習させている。また Kröse and Bunschoten [9] は同様の考え方で、ロボットの位置推定に必要な情報が得られる視線方向を決定する手法を提案している。これらの手法は教示データを用いることにより、位置同定というタスクに関連した注視対象を決定する手法と考えることができる。しかしこれらの手法においてもロボットの行動は反映されていない。ロボットは自らの行動経験を通して、タスクに有効な注視対象を決定するべきである。

一方、生物の脳の視覚野には自らの視覚経験、さらには行動経験に適應して発達する部位が存在する。多くの哺乳動物の脳の皮質視覚野に存在する特徴抽出機能を持つ細胞がその1つである。皮質視覚野には方向、形、色などの特徴に選択的に反応する細胞があり、これらが特徴抽出機能の基礎となっている [10]。そしてこれらの情報に基づいて、シーンの意味付けなどの高次処理が行われる。これらの視覚野神経細胞の視覚機能は生得的に備わっているのではなく、幼若時の視覚体験に適應して形成され

原稿受付

\*大阪大学大学院工学研究科

\*Graduate School of Engineering, Osaka University




Fig. 1 Image feature generation and action selection model

るといふ知見がネコを用いた実験により得られている [11][12]。また自らの運動によるフィードバック的視覚入力が視覚中枢を含めた視覚行動中枢の発達に不可欠であることを示している報告もある [13]。これらの神経生理学的知見から、ロボットの知能の発達においても視覚入力や自らの運動に基づいて特徴抽出器を生成する能力が重要であると考えられる。人工システムにおいては特徴抽出器を学習させた研究として Linsker [14]~[17]の研究がある。これらの研究では単純な多層ネットワークを修正されたヘブ学習則によって学習させることにより、視覚野に見られる方向選択性細胞の機能が自己組織化されて出現することを示している。しかし扱っている問題がすべて視覚情報のみ閉じており、視覚機能の構成に自らの運動が関与していない。

そこで本研究では注視対象としてエッジや視差などのような基本的な画像特徴を扱い、タスク経験から視覚-行動マップの学習を通して画像特徴を生成する手法を提案する。提案する手法では上述した脳構造を反映して、ロボットの状態計算過程を画像特徴抽出部と状態抽出部の2段に分ける。そして画像特徴を抽出するフィルタと状態を計算する写像関数を同時に学習する。学習は状態に関する教示行動のエントロピの最小化により行う。教示したデータを用いることにより、ロボットはタスク達成の経験を通して必要な画像特徴を獲得できる。

従来研究においても、視覚を持つロボットに関してタスクの経験を通してロボットの状態を構築する手法がいくつか提案されている [18]~[20]。ただしこれらの研究では基本的な画像特徴という表現は扱われていない。本手法ではタスクに適した状態を学習すると同時に、タスクに適した画像特徴を学習する。学習された基本画像特徴は選択的注視手法 [21]における注視対象として利用できる。

以下ではまず提案手法の基本的考えを示し、学習方法について詳しく説明する。次に本手法を移動ロボットの室内ナビゲーションタスクおよびサッカーロボットのシュートタスクに適用した実験結果を示し、最後に考察を述べる。

## 2. 画像特徴の生成手法

### 2.1 基本的考え

皮質視覚野ではさまざまな基本特徴を抽出する神経細胞が集まっており、それらの反応（ボトムアップ信号）から脳の別の部位とともに記憶や欲求（トップダウン信号）に基づいて高次処理が行われる。そこで本手法で提案する画像特徴生成モデル

(Fig.1)においても、ロボットの状態を計算する過程を画像特徴抽出部と状態抽出部の2段に分ける。画像特徴抽出部がボトムアップ処理、状態抽出部およびその状態に従って行動を決定する部分が脳の高次処理に相当すると考えることができる。そして実際のタスク経験に基づいて視覚入力と行動間の関係を学習することにより、画像特徴および状態抽出関数を獲得する。

本モデルでは画像特徴を学習するために、それを抽出するためのフィルタを用意し、そのフィルタを学習させる。画像特徴の学習を行うのは、皮質視覚野にある特徴抽出を行う神経細胞の機能が視覚入力に適應して発達するという可塑性を示すことから、人工システムでもそのような発達能力が付与できると考えたためである。たとえばネコの一次視覚野にある方位反応選択性を示す神経細胞が反応する方向は、幼若時の視覚体験に依存して形成されるという報告がある [11][12]。しかしその細胞の方位反応選択性の能力自体は生得的に備わっていると考えられている。このことから本モデルにおいてもフィルタの構造は与え、そのパラメータを学習させる。

ロボットはまず観測画像  $I_o$  に特徴抽出フィルタ  $F$  を全画素に施すことにより特徴画像  $I_f$  を抽出する。次に計算コストを低減するために  $I_f$  を縮小した画像  $I_c$  を計算する。さらに  $I_c$  の全画素の重み付き線形和（重み行列  $W$ ）によってロボットの状態ベクトル  $s$  を抽出する。そしてロボットは状態  $s$  に応じて行動  $a$  を実行する。本手法ではタスク指向的にフィルタ  $F$  および状態写像行列  $W$  を学習するが、前者は局所的な範囲で処理を行い、後者は画像全体にわたる処理を行うことで、学習されるフィルタがより汎用的なものになることを期待する。このような構造は脳内の視覚信号の伝達経路にも見られる。皮質視覚野では網膜に近い部分では神経細胞の受容野は狭く、信号は限られた部分にしか伝わらない。しかし遠のくにつれ受容野の広い神経細胞が現われ、多くの信号が全体に広がることになる（たとえば [22]）。また本手法で学習される状態写像行列  $W$  は状態計算に対して視野内のある領域の重要度を表していると考えることができる。すなわち  $W$  は視野内の注視機構であると考えることができる。

フィルタ  $F$  および状態写像行列  $W$  の学習にタスクに必要な行動を反映させるため、本手法では教示による成功事例を用いる。そして成功事例集合において、状態の行動に関する情報量が最大になるように  $F$  および  $W$  を計算する。

本報告では画像特徴を抽出するフィルタとして、以下に示すような  $3 \times 3$  の空間フィルタ  $F_s$  と色フィルタ  $F_c$  を用意した。

- $3 \times 3$  空間フィルタ  $F_s = (f_{sij}) \in \mathbb{R}^{3 \times 3}$  :

$$\begin{aligned} \bar{I}_{xy} = & f_{s11}I_{x-1y-1} + f_{s12}I_{xy-1} + f_{s13}I_{x+1y-1} \\ & + f_{s21}I_{x-1y} + f_{s22}I_{xy} + f_{s23}I_{x+1y} \\ & + f_{s31}I_{x-1y+1} + f_{s32}I_{xy+1} + f_{s33}I_{x+1y+1}, \end{aligned} \quad (1)$$

$$I_{fxy} = g(\bar{I}_{xy}). \quad (2)$$

- 色フィルタ  $F_c = (f_{ci}) \in \mathbb{R}^3$  :

$$\bar{I}_{xy} = f_{c1}I_{rxy} + f_{c2}I_{gxy} + f_{c3}I_{bxy}, \quad (3)$$

$$I_{fxy} = g(\bar{I}_{xy}), \quad (4)$$

ここで  $x, y$  は画像上の画素の位置,  $I, I_r, I_g, I_b$  はそれぞれ観測画像の輝度, 赤, 緑, 青成分の値を表す. また  $g(\cdot)$  はシグモイド関数である. たとえば以下に示す  $F_s$  は濃淡画像から垂直エッジを抽出するフィルタを,  $F_c$  はカラー画像から輝度値を抽出するフィルタを表す.

$$F_s = \begin{pmatrix} -1 & 0 & 1 \\ -1 & 0 & 1 \\ -1 & 0 & 1 \end{pmatrix}, \quad (5)$$

$$F_c = (0.2990 \quad 0.5870 \quad 0.1140)^T. \quad (6)$$

上述したように, ロボットには式(1)や式(3)のようにフィルタの構造が与えられ, そのパラメータを学習する.

## 2.2 学習手法

ロボットは最初に教示によりタスクの成功事例を収集する. その後オフラインで成功事例から画像特徴および状態画像行列を学習する. 教示段階でロボットはある状況において観測した画像  $I_o$  および, そのとき教示された行動  $a \in \mathcal{R}^l$  の組を教示データとして記憶する.

$$T_i = \langle I_{oi}, a_i \rangle, \quad (7)$$

ここで  $i$  はデータ番号である.  $l$  はロボットの行動空間の次元数であり, 非ホロノミックな拘束を受ける移動ロボットの場合は  $l = 2$  である.

ロボットの状態  $s \in \mathcal{R}^m$  は縮小画像  $I_c$  から  $W \in \mathcal{R}^{m \times n_{cx} \times n_{cy}}$  によって写像される. ここで  $m$  は状態空間の次元数,  $n_{cx}, n_{cy}$  は縮小画像のサイズである. 縮小画像を1次元で表現したベクトルを  $i_c \in \mathcal{R}^{n_{cx} \times n_{cy}}$  とすると状態  $s$  の第  $j$  成分は次式で計算される.

$$s_j = g((W i_c)_j), \quad (8)$$

ここで  $(W i_c)_j$  は  $W i_c$  の第  $j$  成分である.


$F$  および  $W$  は成功事例集合における状態集合  $S$  の行動集合  $A$  に関する情報量を最大化することにより求める. この情報量の最大化は次の条件付エントロピの最小化と等価である.

$$\begin{aligned} H(A|S) &= - \int p(s) \int p(a|s) \log p(a|s) da ds \\ &= - \int \int p(a, s) \log p(a|s) da ds, \end{aligned} \quad (9)$$

ここで  $p(\cdot)$  は確率密度関数である. 式(9)を評価関数として最小化問題を解けばよいが, これを解析的に計算するのは困難であるため本手法では式(9)の代わりに積分を総和で近似した次式の評価関数  $R$  [8] を用いる.

$$\begin{aligned} R &= -\frac{1}{N} \sum_i \log p(a_i | s_i) \\ &= -\frac{1}{N} \sum_i \log \frac{p(a_i, s_i)}{p(s_i)}, \end{aligned} \quad (10)$$

ここで  $N$  は成功事例集合の大きさである.  $p(a, s)$  はデータの発生確率であるので,  $R$  は  $H(A|S)$  をモンテカルロ積分法で計



(a) Task 1

(b) Task 2

Fig. 2 Task

算したものとなっている. 確率密度関数は次式のようにガウシアン平滑化 [23] を用いてモデル化する.

$$p(s) = \frac{1}{N} \sum_q K_s(s, s_q), \quad (11)$$

$$p(a, s) = \frac{1}{N} \sum_q K_a(a, a_q) K_s(s, s_q), \quad (12)$$

ここで

$$K_s(s, s_q) = \frac{1}{(2\pi)^{m/2} h_s^m} \exp\left(-\frac{\|s - s_q\|^2}{2h_s^2}\right), \quad (13)$$

$$K_a(a, a_q) = \frac{1}{(2\pi)^{l/2} h_a^l} \exp\left(-\frac{\|a - a_q\|^2}{2h_a^2}\right), \quad (14)$$

である. また  $h_s$  および  $h_a$  はガウシアンを広がり決定するパラメータである. 評価関数  $R$  が小さくなるにつれ  $p(a|s_i)$  は  $a = a_i$  でピークを持つ単峰性の分布に近づく. すなわちロボットは状態から行動を一意に決定できるようになる.

最急降下法を用いて  $R$  を最小化する  $F$  と  $W$  を同時に求める. 更新式は以下のようになる.

$$F \leftarrow F - \alpha_f \frac{\partial R}{\partial F}, \quad W \leftarrow W - \alpha_w \frac{\partial R}{\partial W}, \quad (15)$$

ここで  $\alpha_f$  および  $\alpha_w$  はステップサイズパラメータである.

学習後ロボットは観測画像から計算した状態  $s$  において最大確率(密度)をとる行動  $a$  を選択して実行する.

$$a = \arg \max_a p(a|s). \quad (16)$$

本手法では式(16)を計算するために粗密戦略を用いる. まず, 全行動空間において粗くサンプル点を設定し, その中で最大値をとる点を全探索により求める. そしてその点付近で2次補間法を用いて最大値をとる行動を求める.

## 3. 実験

### 3.1 タスクと仮定

提案した手法の有効性を検証するため, 実機を用いた実験を行った. タスクとして Fig.2(a) に示した Nomad ベースの移動ロボットによる室内ナビゲーションタスクおよび Fig.2(b) に示したサッカーロボットによるシュートタスクを設定した. (a)

に示す移動ロボットはステレオカメラを装備しており、実験には左カメラ画像のみを用いた．また (b) に示すサッカーロボットは前方に向けられたカメラと全方位画像が観測できるカメラを装備しているが、前者の画像のみを用いた．観測画像の大きさを  $64 \times 54$  とし、輝度成分および色成分の値を  $[0, 1]$  に正規化した．また縮小画像  $I_c$  の大きさを  $8 \times 6$  とした．縮小画像は特徴画像  $I_f$  を  $8 \times 6$  の領域に分割し、各領域の平均値を対応する  $I_c$  の画素の値とした．

各ロボットは並進速度  $v$  および 回転速度  $\omega$  を独立に制御することができる．そこでロボットの行動ベクトルを以下のように設定した．

$$\mathbf{a} = (v, \omega)^T, \quad (17)$$

ここで  $v$  および  $\omega$  の値は  $[-1, 1]$  に正規化した．また状態空間の次元数は  $m = 2$  とした．シグモイド関数  $g$  はすべて以下に示すものを用いた．

$$g(x) = \frac{1}{1 + \exp\left(-\frac{x-\theta}{c}\right)}, \quad (18)$$

ここで  $\theta = 0.0, c = 0.2$  とした．

### 3.2 学習結果

まず始めに教示者がロボットを操縦して成功事例を与えた．ナビゲーションタスク (タスク1) では定められた経路を移動する行動を、シュートタスク (タスク2) ではボールの後ろに回りこんでゴールにシュートする行動を教示した．成功事例数はタスク1では158, タスク2では100であった．教示後それぞれのタスクの成功事例を用いて、画像特徴を空間フィルタ  $F_s$  とした場合および色フィルタ  $F_c$  とした場合について学習させた．フィルタの初期値として以下の値を与えた．また  $W$  の初期値は微小乱数を与えた．

$$F_s = \begin{pmatrix} 0.1 & 0.1 & 0.1 \\ 0.1 & 0.1 & 0.1 \\ 0.1 & 0.1 & 0.1 \end{pmatrix} \quad (\text{平滑化フィルタ}), \quad (19)$$



$$F_c = \begin{pmatrix} 0.2990 \\ 0.5870 \\ 0.1140 \end{pmatrix} \quad (\text{輝度抽出フィルタ}). \quad (20)$$

#### 3.2.1 タスク1：ナビゲーション

まずタスク1についての結果を示す．Fig.3に学習中における評価関数  $R$  の変化を示す．(a) が空間フィルタを用いた場合、(b) が色フィルタを用いた場合である．横軸は更新ステップ数である．ほぼ単調に減少させることができた．また Fig.4 には空間フィルタを用いた場合における学習初期と学習後の事例集合の状態分布を示した．Fig.4 において状態と行動の関係を示すために、便宜上行動を以下のように分類して図中の状態に行動のラベルを付した．

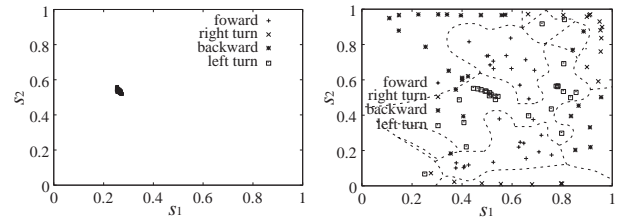
- $v \geq 0.6$  : 前進,
- $v \leq -0.6$  : 後退,
- $-0.6 < v < 0.6$  かつ  $\omega < 0.0$  : 右回転,
- $-0.6 < v < 0.6$  かつ  $\omega > 0.0$  : 左回転.

また図中の破線は式 (16) で行動を求めたときの分布の境界である．この図から互いに近い状態が似た行動に対応するように

(a) Model with  $F_s$ (b) Model with  $F_c$ Fig. 3 Learning curves of  $R$ 

(a) Initial state space

(b) Learned state space

Fig. 4 State distributions (task1,  $F_s$ )

(a) Initial state space

(b) Learned state space

Fig. 5 State distributions (task2,  $F_c$ )



状態空間が構成されていることが分かる．すなわち状態から行動がほぼ一意に決定できるように状態空間が構成されている．しかしこの状態空間の物理的な意味を読み取るのは困難である．

次に生成された空間フィルタ  $F_s$  および色フィルタ  $F_c$  を以下に示す．

$$F_s = \begin{pmatrix} -0.8915 & -0.5995 & -0.06528 \\ -0.9696 & -0.4790 & 1.357 \\ -0.2482 & 0.1021 & 2.756 \end{pmatrix}, \quad (21)$$

$$F_c = \begin{pmatrix} -0.4233 & 1.464 & -0.1718 \end{pmatrix}^T. \quad (22)$$

これらのフィルタを用いて抽出された特徴画像  $I_f$  の例を Fig.6 および Fig.7 に示す．Fig.6 から分かるように生成された空間フィルタは環境中の水平および垂直エッジを抽出する性質を有しており、ロボットがそれらに注意を向けることを学習したと言える．直感的に移動ロボットのナビゲーションタスク

Fig. 6 Example of the filtered image ( $F_s$ )Fig. 7 Example of the filtered image ( $F_c$ )Fig. 8 Example of the filtered image ( $F_s$ )Fig. 9 Example of the filtered image ( $F_c$ )

に有用な画像特徴が生成されたと考えられる．しかし色フィルタには特に顕著な性質は現れていない．これは環境中（研究室内）に顕著な色情報がなかったためと考えられる．

### 3.2.2 タスク2：シュート行動

次にタスク2についての結果を示す．生成された空間フィルタ  $F_s$  および色フィルタ  $F_c$  は以下ようになった．またこれらのフィルタを用いて抽出された特徴画像  $I_f$  の例を Fig.8 および Fig.9 に示した．さらに Fig.5 には色フィルタを用いた場合における学習前後の事例集合の状態分布を示した．

$$F_s = \begin{pmatrix} -3.384 & -1.953 & -1.686 \\ 0.3491 & -1.350 & 0.5363 \\ 1.656 & -1.208 & 5.223 \end{pmatrix}, \quad (23)$$

$$F_c = \begin{pmatrix} 1.836 & 1.616 & -4.569 \end{pmatrix}^T. \quad (24)$$

Fig.8 から生成された空間フィルタは環境中の水平エッジを抽出する性質を有していることが分かる．また Fig.9 から色フィルタは赤いボールおよび黄色いゴールを強調し，白い壁とラインを抑制していることが分かる．これは色の YUV 成分の内の U 成分の反転に相当する性質である．この色フィルタは色情報




Fig. 10 Acquired behavior

で物体識別可能なサッカー競技場においてタスクに有効なものとなっていると考えられる．この環境ではボールの赤，ゴールの黄そしてフィールドの緑が高頻度で出現するが，入力画像に表れる支配的な色を抽出しても Fig.9 のような結果にはならない．たとえば実際に入力画像の RGB 値の主成分を計算すると黄色を表す主成分が現れるが，この主成分軸上で画像を表現しても，Fig.9 のように白と赤，黄が区別されるような結果にはならない．したがって本手法のフィルタの学習は，単に入力画像だけの統計的性質を反映しているのではなく，ロボットのタスクに有効になるように働いていると考えられる．

### 3.3 学習された行動

学習された画像特徴および状態写像行列の有効性を検証するため，タスク1において空間フィルタを用いた場合に学習された  $F_s$  および  $W$  を用いて Nomad ベースの移動ロボットに Fig.2(a) に示すナビゲーションタスクを行わせた．このときのロボットの行動を Fig.10 に示す．

この実験中にロボットが観測した画像およびそれから計算された状態は，学習前に与えられた成功事例中に一致するものがあるとは限らない．それにもかかわらず学習結果を用いて行動決定したロボットは与えられたタスクを達成しており，ある程度環境構造やタスクを反映した画像特徴および状態写像行列を学習していると考えられる．この結果より本手法で提案した Fig.1 のモデルがタスクおよび環境に有効なものとなっていることが示された．

## 4. 考 察

本論文では行動決定に有効な画像特徴および状態写像行列を学習する手法を提案した．そして生成された画像特徴がタスクおよび環境に有効なものであることを示したが，さらに学習された状態写像行列  $W$  が同様に有効な視線選択を表していると考えられる．このことを示すため，例としてタスク1において空間フィルタを用いた場合，およびタスク2において色フィルタを用いた場合に学習された  $W$  の各成分の値を Fig.11 および Fig.12 に示した．これらの図の (a) および (b) はそれぞれ状態ベクトル  $s$  の第1，第2成分の計算に使われる値の絶対値を2次元状に並べたものであり，Fig.6,7,8,9 に示した縮小画像の画素の並びと対応している．絶対値の大きな成分は明るく，小さな成分は暗く示した．ここで明るい部分は状態の計算に大きく関わっており，暗い部分はほとんど関わっていないこととなる．すなわちロボットは視野内で明るい部分の個所を重




Fig. 11 Projection matrix  $W$  (task 1,  $F_s$ )




Fig. 12 Projection matrix  $W$  (task 2,  $F_c$ )

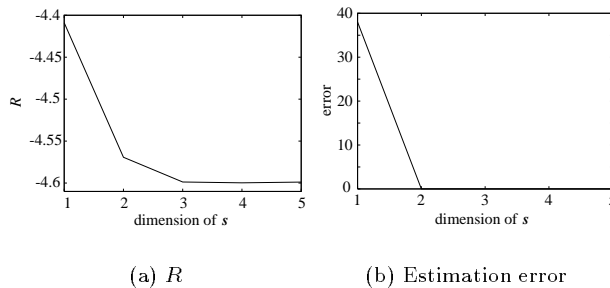


Fig. 13 Effect of the dimension of the state vector

要視し、暗い部分の箇所を無視していると考えられる。このことから学習された  $W$  は行動中は一定ではあるが、視線選択を表現していると考えられる。

本論文では状態ベクトルの次元をあらかじめ2次元に設定したが、次にこの値の妥当性について検証する。そのためにタスク1で空間フィルタを用いた場合について、状態空間の次元数と学習後の評価関数  $R$  の値の関係を調べた。その結果を Fig.13(a) に示す。また次元数と学習後の行動推定誤差との関係を調べた結果を Fig.13(b) に示す。行動推定誤差は学習後に観測画像  $I_o$  から式(16)で推定した行動と  $I_o$  に対応する教示行動との2乗距離の総和である。これらの図から状態ベクトルは行動推定にとって2次元あれば十分であることが分かる。

学習後のロボットは式(16)に従って行動を決定するが、常に行動確率(密度)  $p(a|s)$  が単峰性になっているとは限らない。Fig.10 に示す結果においても  $\max p(a|s)$  が比較的低い値を示す状況が存在する。このような状況ではロボットの行動決定信頼度は低いものとなる。したがってロボットは常に単一の画像特徴に注意を向けるのではなく、様々な環境やタスクで学習した複数の基本的な画像特徴に選択的に注意を向けることによって、より複雑な環境やタスクに適応することが必要であると考えられる。そこで本論文で提案した手法を情報量を基準とした選択的注視手法[21]に適用することが考えられる。

## 5. おわりに

本論文ではロボット自身が視覚-行動マップ学習を通して、行動決定に有効な画像特徴および状態写像行列を学習する手法を提案した。提案したモデルは視野内の注視対象をロボット自身が学習できるものとなっている。そして実機を用いた実験により、生成された画像特徴がタスクおよび環境に有効なものであることを検証した。

人間を始めとする多くの哺乳類の脳は、知覚だけではなく身体行動と環境との相互作用を通して、その機能を発達させていると考えられている。本手法の2段階構造において、画像特徴部に Fig.6,8,9 のような汎用的なものが現われたことは、視覚野に見られる基本特徴に反応する部位が環境との相互作用により発達しているという知見とのアナロジーをとることができるのではないかと考えられる。今後はこのようなアナロジーを詳細に調べることにより、提案したモデルの振る舞いから脳発達のモデルを与えることが期待される。そのためのアプローチとして、環境を変化させたときに画像特徴や視線選択がどのように変化、あるいは発達していくかを調べるのが考えられる。

## 参考文献

- [1] A. Treisman and A. Gelade. A feature integration theory of attention. *Cognitive Psychology*, Vol. 12, pp. 97-136, 1980.
- [2] J. M. Wolfe, K. R. Cave, and S. L. Franzel. Guided search: An alternative to the feature integration model. *Journal of Experimental Psychology: Human Perception and Performance*, Vol. 15, No. 3, pp. 419-433, 1989.
- [3] 横澤一彦. 多解像度モデルによる視覚的注意と視覚探索の分析. 認知科学, Vol. 1, No. 2, pp. 64-82, 1994.
- [4] P. Laar and S. Gielen. Task-dependent learning of attention. *Neural Networks*, Vol. 10, No. 6, pp. 981-992, 1997.
- [5] 竹内義則, 大西昇, 杉江昇. 情報理論に基づいたアクティブビジョンシステム. 電子情報通信学会論文誌 D-II, Vol. 81-D-II, No. 2, pp. 323-330, 1998.
- [6] T. Arbel and F. P. Ferrie. Viewpoint selection by navigation through entropy maps. In *Proceedings of the Seventh International Conference on Computer Vision*, pp. 248-254, 1999.
- [7] S. Thrun. Bayesian landmark learning for mobile robot localization. *Machine Learning*, Vol. 31, No. 1, 1998.
- [8] N. Vlassis, R. Bunschoten, and B. Kröse. Learning task-relevant features from robot data. In *Proceedings of the 2001 IEEE International Conference on Robotics and Automation*, pp. 499-504, 2001.
- [9] B. J. A. Kröse and R. Bunschoten. Probabilistic localization by appearance models and active vision. In *Proceedings of the 1999 IEEE International Conference on Robotics and Automation*, pp. 2255-2260, 1999.
- [10] 入来正躬, 外山敬介(編). 生理学, 第II章. 文光堂, 1986.
- [11] H. V. B. Hirsch and D. N. Spinelli. Visual experience modifies distribution of horizontally and vertically oriented receptive fields in cats. *Science*, Vol. 168, pp. 869-871, 1970.
- [12] C. Blakemore and G. F. Cooper. Development of the brain depends on the visual environment. *Nature*, Vol. 228, pp. 477-478, 1970.
- [13] R. Held and A. Hein. Movement-produced simulation in the development of visually guided behavior. *Comparative and Physiological Psychology*, Vol. 56, pp. 872-876, 1963.
- [14] Ralph Linsker. From basic network principles to neural architecture: Emergence of spatial-opponent cells. *Proceedings of the National Academy of Science of the United States of America*.

- ica, Vol. 83, No. 19, pp. 7508–7512, 1986.
- [15] Ralph Linsker. From basic network principles to neural architecture: Emergence of spatial-oponent cells. *Proceedings of the National Academy of Science of the United States of America*, Vol. 83, No. 21, pp. 8390–8394, 1986.
- [16] Ralph Linsker. From basic network principles to neural architecture: Emergence of spatial-oponent cells. *Proceedings of the National Academy of Science of the United States of America*, Vol. 83, No. 22, pp. 8779–8783, 1986.
- [17] Ralph Linsker. Self-organization in a perceptual network. *Computer*, Vol. 21, No. 3, pp. 105–117, 1998.
- [18] 中村恭之. 視覚移動ロボットのタスク達成のための状態空間の自律的構成手法. 日本ロボット学会第15回学術講演会予稿集, pp. 139–140, 1997.
- [19] T. Nakamura. Self-organizing internal representation for behavior acquisition of vision-based mobile robots. In *Proceedings of the fourth International Conference on Simulation of Adaptive Behavior: From Animals to Animals 5*, pp. 104–113, 1998.
- [20] H. Ishiguro, M. Kamiharako, and T. Ishida. State space construction by attention control. In *Proceedings of the Sixteenth International Joint Conference on Artificial Intelligence*, pp. 1131–1137, 1999.
- [21] 港隆史, 浅田稔. 移動ロボットのための情報理論に基づく選択的注視機構. 日本ロボット学会第18回学術講演会予稿集, pp. 811–812, 2000.
- [22] D. J. Fellman and D. C. Van Essen. Distributed hierarchical processing in the primate cerebral cortex. *Cerebral Cortex*, Vol. 1, pp. 1–47, 1991.
- [23] M. P. Wand and M. C. Jones. *Kernel Smoothing*. Chapman & Hall, 1995.

#### 港 隆史 (Takashi Minato)

1998年大阪大学大学院工学研究科博士前期課程修了。2001年12月科学技術振興事業団CREST研究員。2002年9月大阪大学大学院工学研究科助手となり現在に至る。知能ロボットの研究に従事。  
(日本ロボット学会正会員)

#### 浅田 稔 (Minoru Asada)

1982年大阪大学大学院基礎工学研究科後期課程修了。同年、大阪大学基礎工学部助手。1989年大阪大学工学部助教授。1995年同教授。1997年大阪大学大学院工学研究科知能・機能創成工学専攻教授となり現在に至る。この間、1986年から1年間米国メリーランド大学客員研究員。知能ロボットの研究に従事。1989年、情報処理学会研究賞、1992年、IEEE/RSJ IROS'92 Best Paper Award受賞。1996年日本ロボット学会論文賞受賞。博士(工学)。ロボカップ国際委員会副委員長、ロボカップ日本委員会委員長、電子情報通信学会、情報処理学会、人工知能学会、日本機械学会、計測自動制御学会、システム制御情報学会、IEEE R&A, CS, SMC societiesなどの会員。  
(日本ロボット学会正会員)